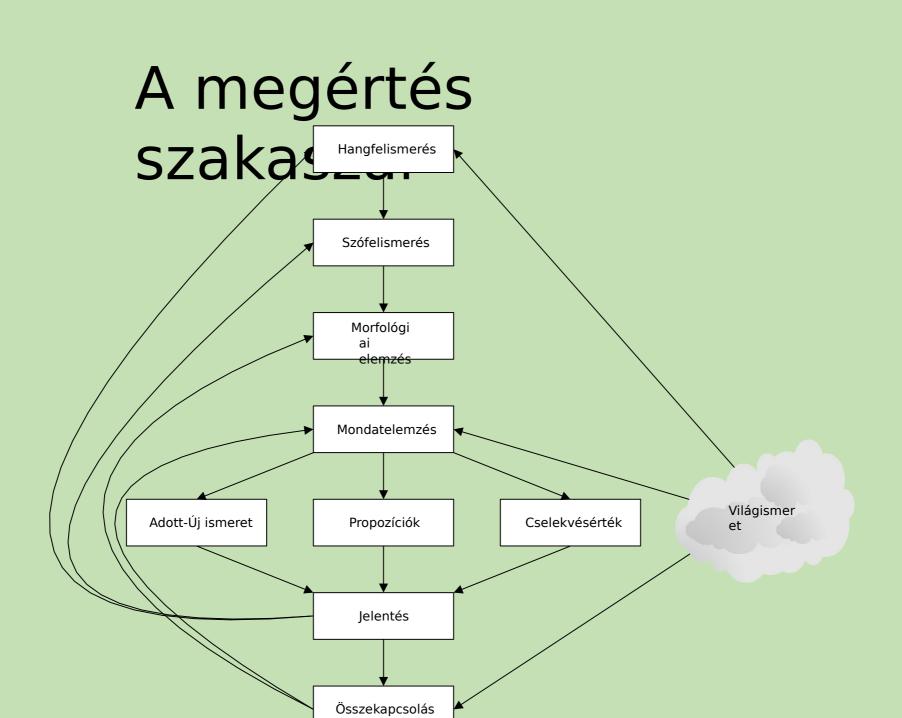
A nyelvi megértés folyamata: információ és szabályok Pléh Csaba

# vispleh@ceu.

- Előadás a Paletta sorozatban. Wesley János Főiskola
- \*2020.Október 17



#### Statisztika és szabályok örök versenye

- RENDEZETLENSÉG CSÖKKENTÉS
- A szófelismerés információs értelmezése.
- A morfológia információelméleti értelmezése. A morfológiai modellek kvantitatív értelmezése.
- A mondattan információs megközelítése.
- A priming folyamatok általános érdekessége..
   Szövegmegértési sémamodellek és az információ. Kintsch információintegrálási felfogása.
- Szabály és statisztika kettős modellek. Pinker, Ullman.

- A VÁRATLAN KEZELÉSE
- A megértés folyamatának komponensei és a nyelvi szintek
- A megértés gyorsasága. Találatok és Tévedések versengése
- Alternatív felfogások: modulok és interakciók
- A tudás és az inger viszonya. Elvárások a megértésben
- Lexikai emlékezet, világismeret és információ

Eliza: "pszichoterape uta" Weisenbaum 1966. mlt hallunk bele statisztika alapján? A férfiak mind egyformák.

Ezt hogy érted?

Mindig nyaggatnak minket valamiért.

Mondanál egy konkrét példát?

Hát, a fiúm küldött ide.

A fiúd küldött ide.

Azt mondja, mindig depressziós vagyok. Sajnálom, hogy depressziós vagy.

Talán ki kellene békülnöm az anyámmal. Mesélj még a családodról.

- A módszer:
  - Kulcsszókeresés
    - mindig
    - anyám
  - Kulcsszó aktivál egy szabályt
    - Mondanál egy konkrét példát?
    - Mesélj még a családodról.
  - Reguláris kifejezések segítségével behelyettesítés a szabálynak megfelelően
    - fiúm -> fiúd
  - A kulcsszavak rangsorolva vannak

# Mi ELISSA tanulság a?

Sok emberi folyamat algoritmizálható

Nem is olyan elvont az ember

Kérdés, hogy olyan-e ez, mintha átmenne a Turing próbán?

Mi a statisztika szerepe az önbecsapásban?

Hogyan lehet becsapni?

És a valódi pszichológust?

#### Vissza a laborbaa Találatok és Tévedések

versengéseA kontextus

- A kontextus
   támogat : Találat
- A kontextus félrevezet

Tévedés



 Kinyitom ajtót a kuxxxx

.

kulccs

J

kutyán

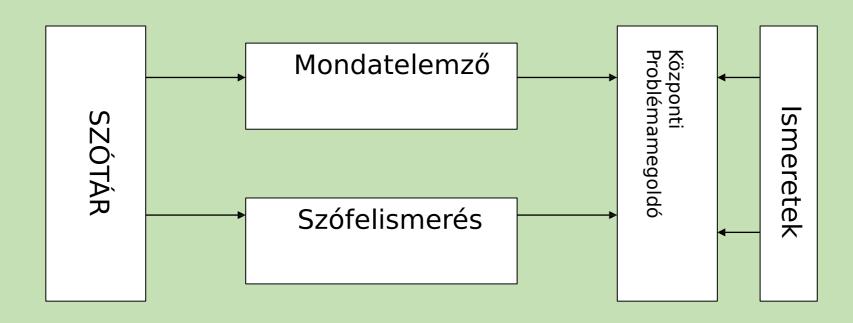
ak

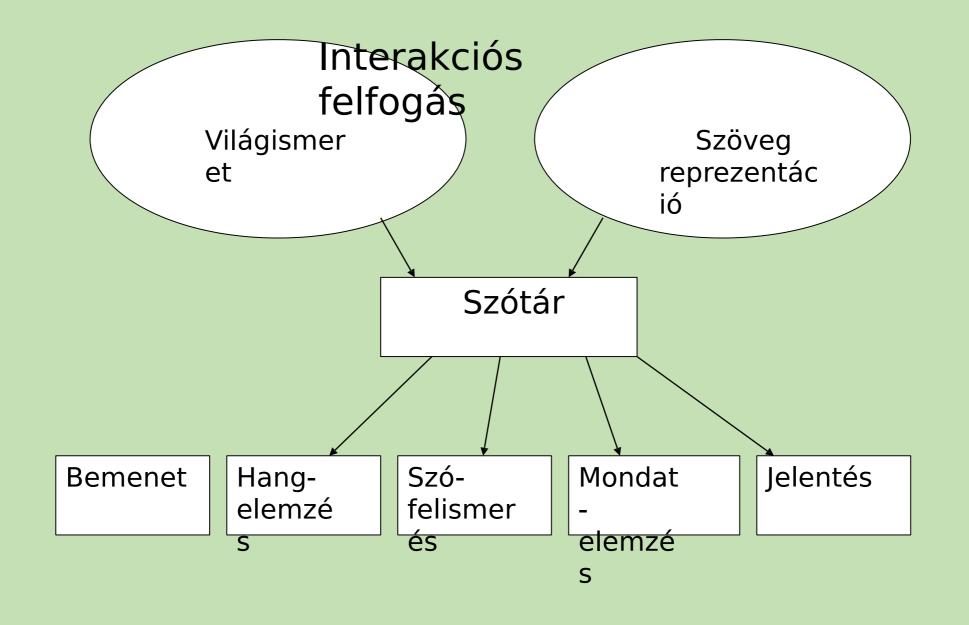
#### A megértés folyamatának komponensei. A nyelvi felfogásban

- Moduláris felfogás
- Rögzített összetevők
- Alulról-felfelé
- Forma-jelentés
- Ostoba feldolgozás
- Algoritmik us

- Interakciós felfogás
- Hajlékony összetevők
- Felülről-lefelé is
- Elvárások döntőek
- Értelmes integráció
- Heurisztikus megoldások

# Modularista modell





#### A nyelvészeti információelméleti érdeklődés szakaszai

 Korai lelkesedés: Nyelvészeti kritika Visszajön a statisztika a statisztika







- •1950 Shannon
- Miller

1960 Chomsky

G. Miller

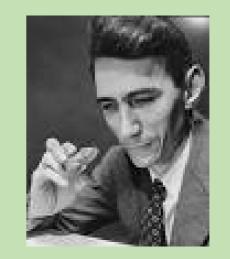
1990 Kostic

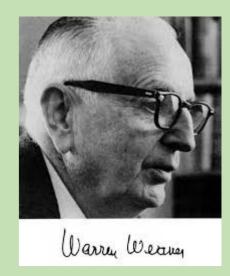
Bayern Saffran

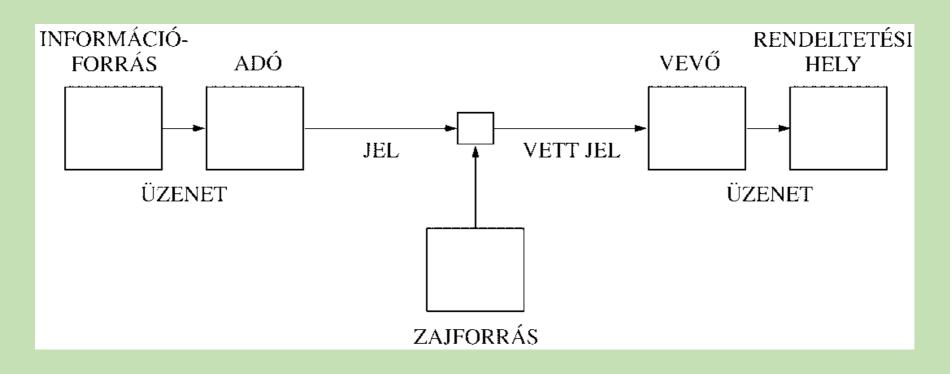
#### Kiinduló Shannon Weaver modell

? Hol a kód?

? Hol a jelentés ?







## Alapfogalmak

- Információ és bizonytalanság
- Rendszerek átlagos információértéke és a lehetséges jelszám. ÁBC nagyságtól függ
- Átlagos információ log N
- Bináris egységekben, kettes alapú log.
- Miért?
  - neuro
  - optimális keresés
  - természeti folyamatok csillapítása

# Találjuk ki

Gondoltam egy 0... 9 közti számot

Gondoltam egy betűt

# Az entrópia általános

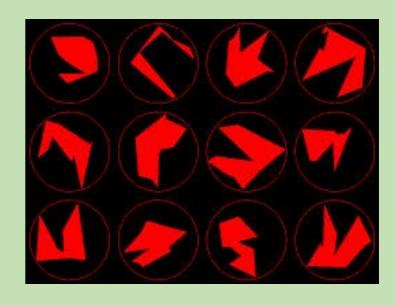
képlete

$$H = -\sum p_i \log p_i$$

#### Entrópia változásai

- Maximális ha minden p egyforma
- Ha vannak kiemelt valószínűségű jelek, csökken a rendezetlenség
- Redundancia: a H (max) és a H(megfigyelt) viszonya
- A struktúra kérdése vizuális formáknál Attneave és Garner
- Akkor a Gestalt szerveződés alacsony információ lenne?
- Vagy éppen a hirtelen
- változás adja a formát?



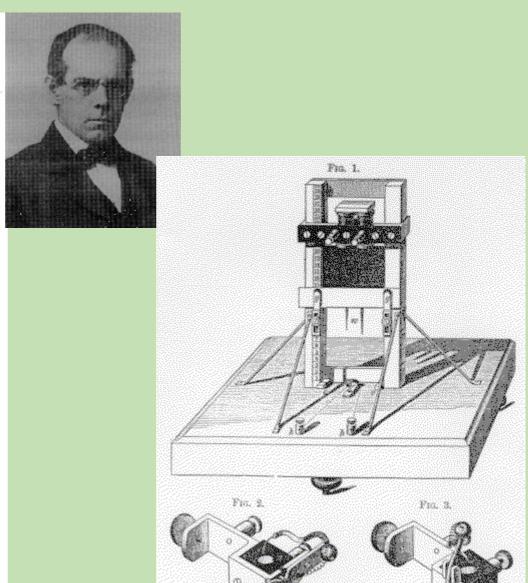


A statisztikai múlt az észlelésre : A gyakoriság szerepe

- Cattell, 1886:. Szavak olvasása. Még embert vizsgálunk, de már a rendszer is érdekel
- It will be noticed that the perceptiontime is only slightly longer for a word than for a single letter; we do not therefore perceive separately the letters of which a word is composed, but the word as a whole. The application of this to teaching children to read is evident

TABLE XXVI.

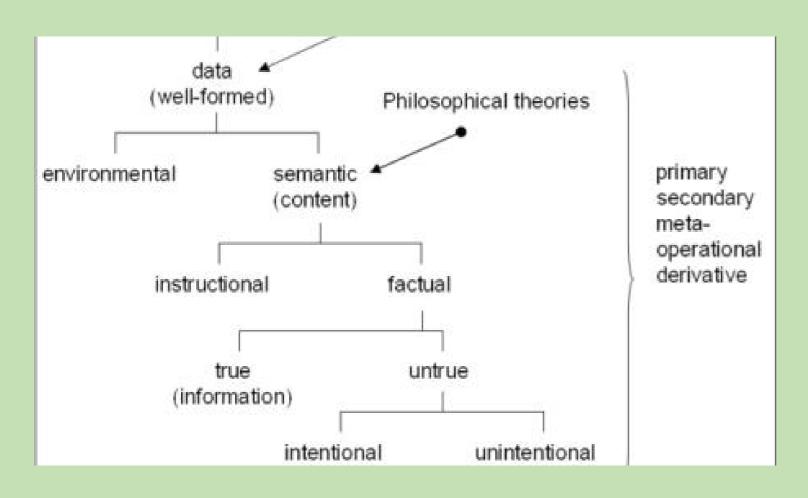
17		Hand.				LIP-KEY.				
		В		C		2	В		C	
		R	R'	R	R'		R	R'	R	R'
Mind	12. XII.	353	352	337	329	13. I	360	366	374	364
Life	15		351	373	377		366	367	363	365
Time	16	333	330	375	372	15	311			
	10	377	366	383		10	911	312	371	366
House			NO. 35.074		389	7.5	331	324	355	
Child		345	343	328	339	17	347	341	370	375
Year	18	353	359	369	360		337	336	354	358
Truth	1	352	329	376	367	29	302	311	360	353
Name	been h	341	339	392	393		313	315	374	380
Light	19	332	328	327	323		325	332	372	372
Ship		318	313	336	332		294	302	340	340
A		345	341	360	358		329	331	363	363
AV		24	13	26	17		23	12	28	20
False		2		4			7		0	
Education	5. I	331	331	346	348	17. I	349	345	382	386
Philosophy	0. 1	330	322	349	354	**********	347	351		
Knowledge	7		337			22			376	
	f	341		366	360	22	353	348	329	319
Architecture.	120	377	375	382	377	1200	357	355	336	340
Literature	10	339	320	363	354	23	333	332	377	382
Temperance.	20	341	333	399	404		339	330	377	376
Ignorance	1	300	297	380	369	1	325	319	378	382
Physician		325	329	380	375	26	339	333	351	346
Enthusiasm.	12	334	337	405	409		353	349	409	400
Imagination.		321	317	384	375	2	342	337	395	391
A		334	330	375	373		344	340	371	370
AV	77-2	25	16	28	19		23	15	27	17
False		-8		8			6		9	
Buch	24. I	290	294	367	363	23. I	315	318	359	355
Zahl		309	311	380	378	A. A	310	319	370	378
Kuust		307	309	369	374		310	314	362	352
Walt		308	307	1000		1		12000000		
Welt	26			361	353	0.4	308	305	362	362
Haus	20	295	292	354	353	24	299	297	339	344
Licht		324	323	354	359		330	329	356	350
Kind	iona.	323	323	377	380	9002	303	308	352	356
Land	29	309	307	363	365	26	316	321	373	365
Traum	21	321	316	377	376		324	325	368	373
Jahr		319	318	365	368		321	325	374	378
A		311	310	367	367		314	316	362	361
AV		14	9	20	13		17	12	31	20
False		6		5			10		7	



### A szavak gyakorisága gyakran felmerül

- Olvasás és szókincs tudás mérés megalapozásához
- Asszociatív adatok értelmezéséhez
- Betegek bizarr beszédének interpretáláshoz
- Még stílus statisztikák is megjelennek
- Legfeljebb szófajban jellemezve a szavak

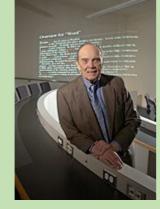
# Az információ sokrétű fogalom



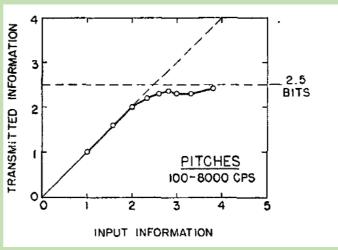
- Miért ,szintaktikai' a Shannon féle?
- Mi informatívabb köznapilag: kutya vagy állat? S melyik ritkább?
- Szemantikai elméletek
- Bar Hillel MacKay
- Igazság és p ill. diszkriminatív érték

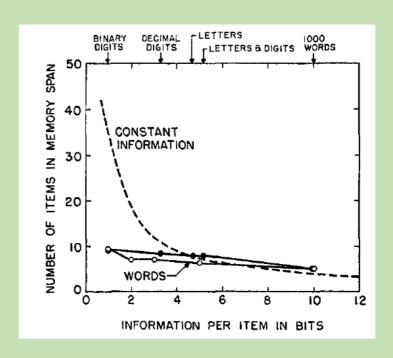
Mire vagyunk limitálva? Miller felismerései

Abszolút ítélet: 2-4 bit, 4-8 színt



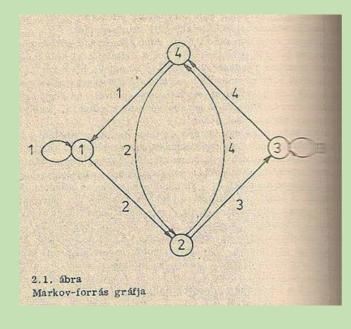
 Munkamemória: 7 ± 2 egység, s nem info csatorna. ,Tömb' határ





#### Miller és Chomsky megfordítják a trendet: mindez legfeljebb egy gyenge Markov modell





- A Chomsky hierarchia és a pszicholingvisztika
- Nemcsak a nyelvtanra, hanem a nyelvi viselkedésre is algebrai modell kell
- Abból is nem akármilyen
- Véges állapotú nem elég
- Az ellenérdekeltek szerint igen, ha a gráf ágaihoz valószínűségeket rendelünk

# Visszatérő kérdések minden elemzési

1. Az általá**színten** angtípus, szófaj stb

2. Statisztika és szabályok viszonya

3. Alulról-felfelé és Felülről-lefelé áramlás

4. Helyzethez igazodás és tanulás

# A kontextus hatások a hangok, szavak, és

Gy**Szerice** (n**Szerice**) fertesi terrents 140-180 szó, 3-4 szó/sec. Mesterségesen felgyorsított beszéd: akár a normális sebesség kétszeresével mondott beszédet is megértjük.

Pollack és Pickett (1964) természetes beszélgetésből kivágott egyedi szavakat izoláltan mutattak be: felismerhetetlenek voltak. Mondatba visszarakva tisztán felismerhetőek voltak.

Nyelvtani szerkezetek és a statisztika teszi lehetővé, hogy jóslásokat tegyünk beszéd közben. A leggyakrabban használt 50 angol szó a beszélt szövegek 60%-át, az írottak 45%-át teszi ki.

A kulccsal kinyitottam ⇒ STATISZTIK

Aitóulccsal kinyitottam ⇒ az ajtót

#### Tévedések a szófelismerésben Gósy Mária gyűjtése

szint	eredeti forma	meghallott forma	értelmezés	
hangészlelés	gőzös hajó	közös hajó	hang hasonlóság	
szófelismerés	vélelem	védelem	gyakoribb szó	
morfológia	fejez	fejes	gyakoribb rag	
morfológia	leszedték a zárakat	leszedték az árakat	hibás tagolás	
mondatelemzés	kerget a lányod	kergeti a lányodat	egyértelműsíté s	
jelentés	hallod lám	hallomás	értelmezés	
szövegösszefügg és	csak egy játékszer	csak egy pár ékszer	ékszerboltban	

# Statisztik a és szabályo viszonya

#### A hangok elvárt sorrendjei:

- Ritka *kra pro*
- Vajon ez segíti vagy nehezíti-e az észlelést?
- Statisztikai tény-e, hogy az ik és az ás szóvég gyakori, vagy nyelvtani, szabályalapú hatás?

\* kp , tv

# Áttekintés az entrópia kihívásról

- Kezdeti lelkesedés. Chomsky kritikája
- Az utóbbi évtized a nagy digitális szöveganyagok révén: Shannon reneszánsz
- Négy példa:
- Szófelismerés Akusztikus bejóslási (gating) és olvasott szavakra vonatkozó szótári döntés
- Alaktani döntések és entrópia
- Szótári és alaktani entrópia viszonya
- Vonzat bejóslás és bizonytalanság
- Szerkezeti megfontolások mellett az entrópia változás segítségével magyarázni.

### Csaba Dani Dani Kornél Klára Judit







Entrópia









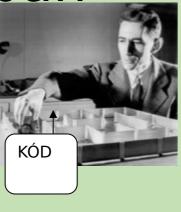
Gating

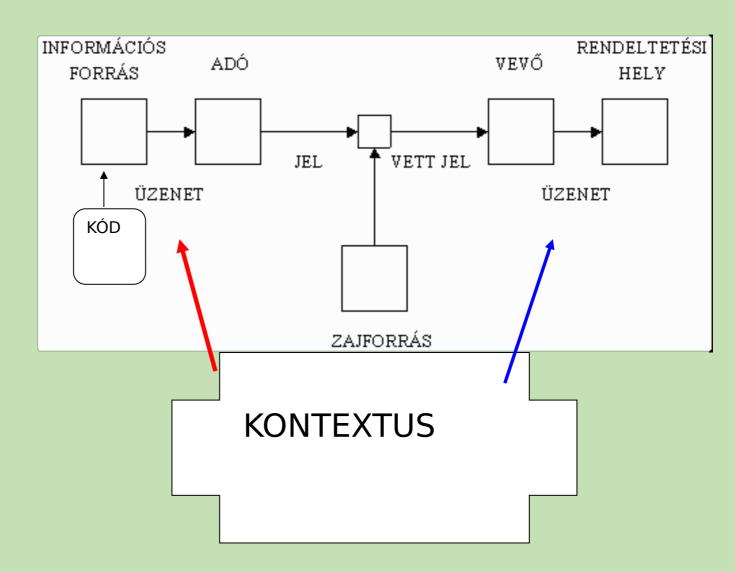
LexDec

Priming

Információelmélet és nyelv Shannon

korában





# Nyelvi következmények

• 1. feldolgozási korlát és átvitt információ

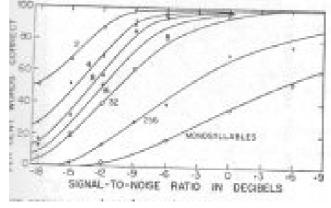
• 2. redundancia és szófelismerés

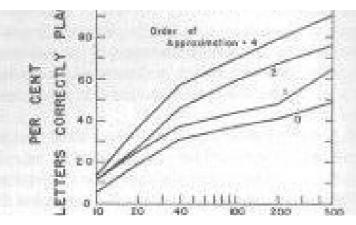
 3. statisztikai közelítések a nyelvhez és a feldolgozhatóság Néhány klasszikus szófelismeré si hatás Miller, 1951 alapján

Hatás jellege	Modalitá s	Változók	Fő eredmény
Expozíciós idő a gyakoriság függvénye	Vizuális	Gyakoriság és felismerési idő	Logaritmikus függvény, megfelel az információnak
Zaj rontja a felismerést	Akuszt	Jel-zaj arány,szóhos sz	Felismerés zajban romlik
Expozíciós idő javítja a felismerést	Vizuális	Idő hatása 0-55 ms Statisztikai közelítés	Idő javít, de a statisztika hasonlóság ugyanígy
Nyelvtani szerveződé s javít	Akuszti kus	Jel-zaj arány, szótag, szavak, mondatok	Mondat >szó>szótag zajban
Mondatkontext us	Akuszti kus	Jel-zaj arány, elszigetelt szó és mondat	Mondat segíti felismerést

### Információelméleti észlelés kutatás

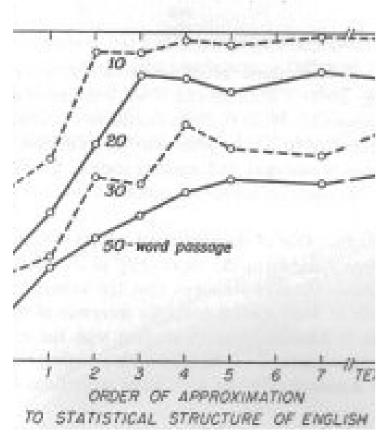


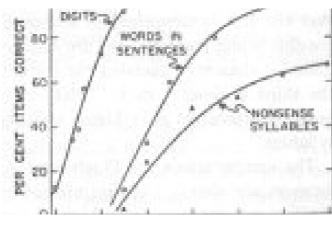


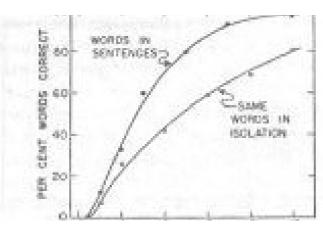


- G. A. Miller
- Zaj és észlelés
- Expoziciós idő és felismerés

### Kiterjesztve a nyelvre



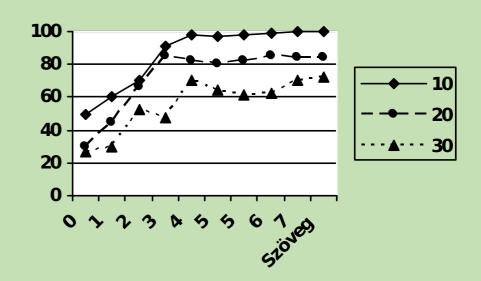




- Értelmességhatás
- Szavak és mondatok
- Statisztikai közelítés szintje

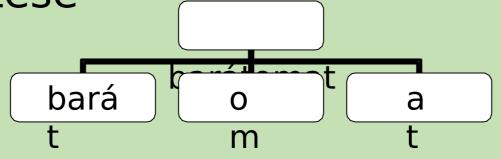
#### Statisztikai közelítések

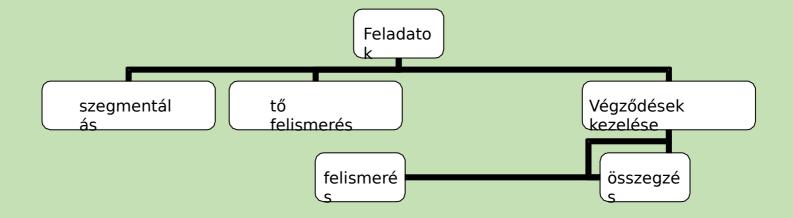
- 0-d rendű: *mellékesen következmény csinosan bankár hajlik áram*
- 1. rendű : *képesség révén mely engem keringő téged a varrás*
- 4. rendű : *láttam a meccset* befejezik szilveszter éjjel
- 7 rendű : *ismerem zenei képességeit miután bemutatta előtte*



### A szavak

világa • Tövek és végződések: a szavak felépítése





# Szavak felismerése és a mentális

- Hozzáférési utak: akusztikus, grafémikus, közös.
- Általánosítás 1: a jelentés egy közös szótárban Általánosítás 2: a hó és a hav a Hóhoz kapcsol Általánosítás 3: a szófaj is tárolva van, s sok mindent elárul

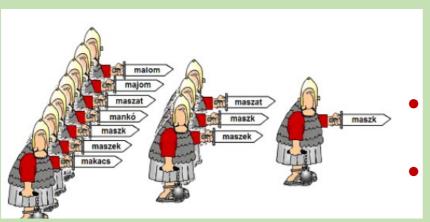
pl. kabát \*ik hisz a kabát főnév

Küszöb és alapszint változások:

## A szófelismerés modelljei Cohort-modell - hallott szavak felismerése már az első szótag alapján

 McClelland & Rummelhart (1981) - vizuális felismerégia modella versengésről

- Marslen-Wilson (1987)
  - Kompatibilis szavak automatikus aktivációja
    - Kiválasztás



összefüggő szöveg – erős igazodás

betűdetektor

Aktiválódott

jegydetektor

inger

izolált szavaknál & értelmetlen szövegek – kevesebb az elvárási hatás

FOFK

WORK

WORD

WORK

oo de ka

## GAIING - a paradigma

- Bevett szófelismerés vizsgáló eljárás
- Nincsenek magyar adatok
- Jól kontrollálható változók
- Francois Grosjean (1980)
  - melyek a szófelismerés kritikus pontjai?
  - személy szavakból hallgat egyre nagyobb részeket
  - Hatások:
    - Gyakoriság (gyakoribbak rosszabb teljesítmény)
    - Szóhosszúság (hosszabb szavak rosszabb teljesítmény)
    - Kontextus (mondatba foglalva jobb a teljesítmény)
  - a növekvő, sorozatszerű, inkrementális bemutatásnak nincs hatása (Cotton és Grosjean, 1984)

## Ingerek

# 60 szó a szószablyából

30 ritka (<152; ~67,23)

15 korai

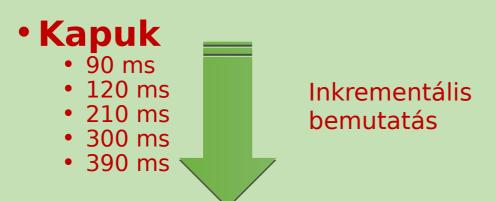
15 késői egyediségi pontú egyediségi pontú 30 gyakori (>11982; ~55770)

egyediségi pontú

egyediségi pontú

	szó	9 5	Lemm	gyed. pont	Első 4	entrópi a		szó	gyakoris ág	Le "yak.	d.	Első 4	entrópi a	
	böllér	8		3	h ä II	0,6030		asszon					1,5409	
	cé		196	3	böll cécó	96		y fórum	50211 167634	7569	3	assz fóru	12 0	
	CSObe			3	csöb	0		szoftv er	31974	71251	2	zof	0,0766 25	
	a	77	186	3	dunn	0,6523 52	Ko	utca	50381	141877		utca	1,0199 15	
	Jd	128	173	3	dzsú	1,1398	rai	pápa	25598	34252	3		1,0693	
			172	3	güzü	0,5832 07	di	szféra	11602	26148	3	szfé	0,0455 89	
	/US-		6	3	gyűs	1,4724 54		tonna	11982			comi	),5976 95	
	kégli	66	181	3	kégl	0		 eg		28887	3	,,,	3,0046 82	
	lucso	66	156	3					83	33280		keny	1,0819	
			174	3		0		típus		52944	3	tín		
	poes k		7	3	pőcs			műsc	17263	B	3	műsr	209	
	rücsö	8	45	3	rücs	0,45		ablak •		70943	3	alp	0,8372 88	
	Se		128	3	sass	1,8494 19	_	dollár	13876	38662	3	dol	0,020	
		14	34	3	üzér	0,4435 76	sői	ünnep	12579	50454	2	ünne	32 ,2139	
	epi	63	151	3	zsep	0	<b>30</b> 1	japán	17879	36339	3	japá	,2139 08	
		0	161	5	bögö	0		család	71077	218999	5	csal		
	cinke	3	185	5	cink	1,9482 23		kérdés	133771	573154	5	kérd	1,4260 39	
	dublő	21	0.7	5		1 5944							0.7521	

## A gyakorlatban



- A szavak sorrendje random
- Ha helyes volt egy adott kapunál a válasz (KV regisztrálja a RI mérést követően (csak 2. kísérlet) – SRB, mikrofon), akkor ugrik a következő szó 1. kapujára (90 ms)

#### Konfidencia döntés

- 1 egyáltalán nem biztos
- 2 inkább nem biztos
- 3 inkább biztos
- 4 teljesen biztos

#### Gating - a szógyakoriság és az egyediségi pont hatása a szófelismerésre

- Gyakori korai
- Gyakori késői
- Ritka korai
- Ritka késői

90 (ms)

**=** 

120

210

- ablak

390

300

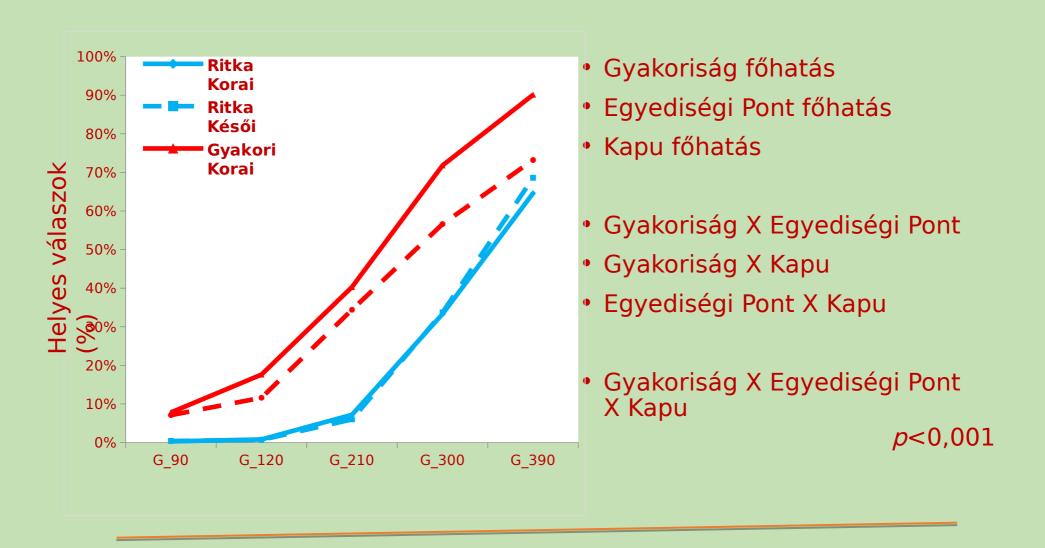
nemzet

- ≣)
- ≣♪
- **=**
- **=**

tartár

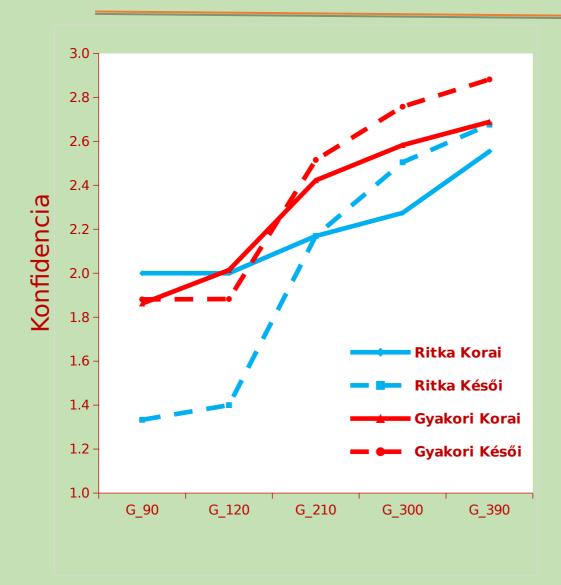
böllér

## I. Kísérlet - pontosság



**51 résztvevő; 20 férfi** (21,12 év, *SD*=1,37) és **31 nő** (20,41 év,

### I. Kísérlet - konfidencia



- Gyakoriság főhatás
- Egyediségi Pont főhatás
- Kapu főhatás
- Gyakoriság X Egyediségi Pont
- Gyakoriság X Kapu
- Egyediségi Pont X Kapu
- Gyakoriság X Egyediségi Pont X Kapu

*p*<0,001

### Összeségében

- Egy szótag elég a felismeréshez pl. megfelelően a kohorsz elméletnek
- Minél korábbi az egyediség, annál korábbi a felismerés
- Gyakoriság segít
- Ritka szavak inkább alulról-felfelé
- Nyelvtani és fonotaktikai megszorítás is segít

### Gating és entrópia

- **Prefixtypeoccurenceslog:** Az adott prefixummal kezdődő szótárban előforduló szavak számának 2-es alapú logaritmusa
- **prefixfreqlog:** Az adott prefixummal kezdődő, szótárban előforduló tokenek számának 2-es alapú logaritmusa
- entrópia A webkorpusz feltételes entrópiája, adott prefixum feltételezése mellett. Informálisan, a fennmaradó bizonytalanságunk mértéke, amikor egy ismeretlen szó egy adott kezdőszeletét már megismertük.

$$H(W|x) = \sum_{w \in W} p(w|x) \log p(w|x)$$

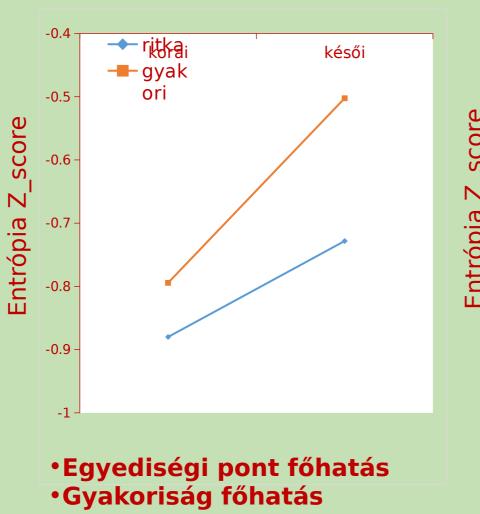
• entropychange – az entrópia csökkenése az előző kapuhoz képest (1. kapunál nincs értelmezve).

### Felhasznált MOKK korpusz

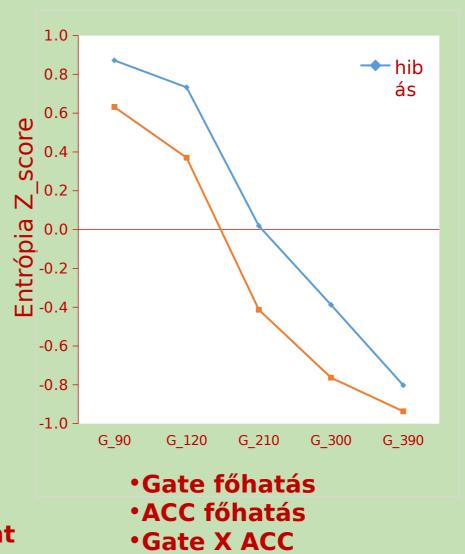


Korpusz	Oldal (millió)	token (millió	type (millió)
Teljes	3,5	1486	19,1
60% Idegen kiiktat	3,125	1310	15,4
92% Csak diakritikus	1,918	928	10,9
96% Elütés mint a normálban	1,221	589	7,2

### Gating és entrópia



 Gyakoriság X Egyediségi pont interakció



interakció

### II. Kísérlet

#### GATING

- Megszorítás Főnév
  megszorítás nélkül (Instrukció)
- "On-line" feldolgozáshoz közelebb áll
  - RT (response box mikrofon)
  - Konfidencia-ítélet (1-2-3-4)

#### Résztvevők

• 14 fő (7 férfi (28,16 év, *SD*=14,05), 7 nő (28,0 év, SD=13,14)

#### Ingerek

Ugyanaz, mint az 1. kísérletben

### Az instrukció

Szavak részleteit fogod hallani. A feladatod, hogy kitaláld, mi lehet a szó.

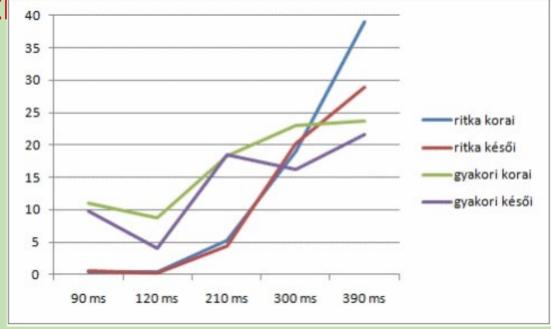
Azt is meg kell mondd a válasz után, hogy mennyire vagy biztos abban, hogy a tipped helyes volt. Minden elhangzott részlet után válaszolnod kell és biztossági ítéletet kell hoznod, de mindig csak az aktuális elhangzott részletre vonatkozóan.

Indulhat a feladat?

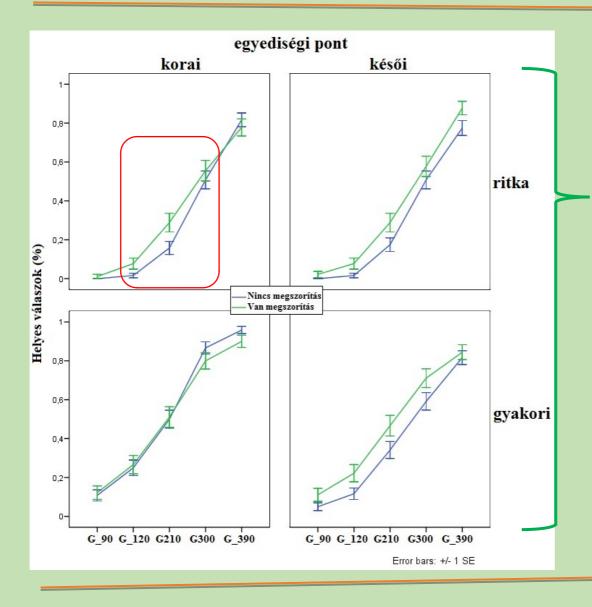
(Tedd fel a fülhallgatót!)

#### Felülről-Lefelé hatások

 Le lehet-e szűkíteni egy adott csoport a keresést?

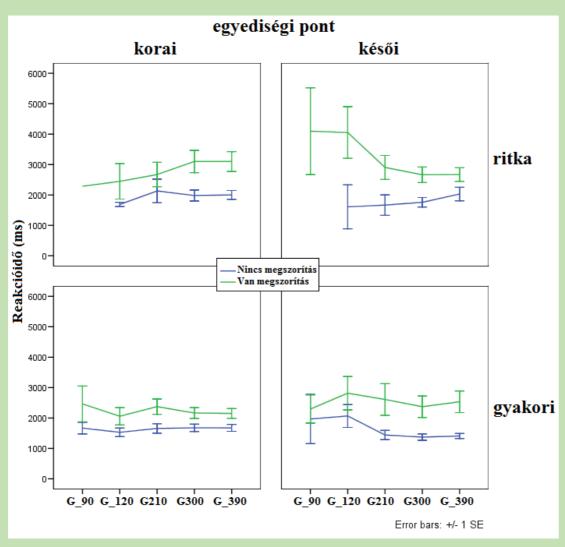


### Pontosság



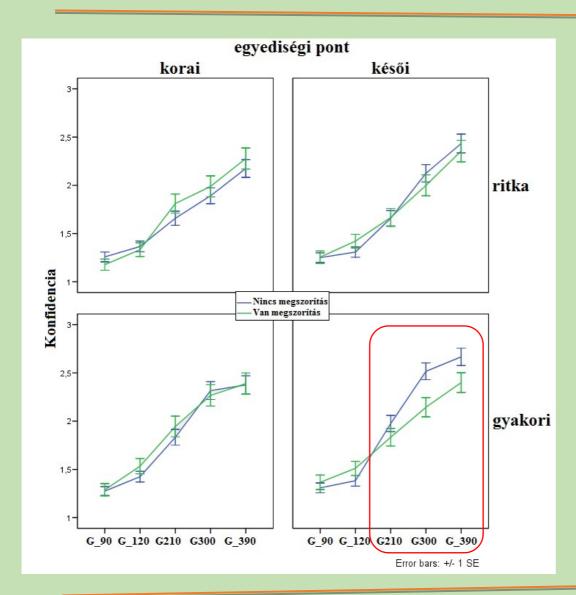
- A korai egyediségi pontúak esetén a kisebb kapuknál segít, a megszorítás
- A megszorítás a pontosságot a késői egyediségi pontú ingerek esetén növeli (gyakoriságtól függetlenül)

#### Reakcióidő



- a megszorítástól lassabbak lesznek a reakcióidők függetlenül a gyakoriságtól és az egyediségi ponttól.
- a ritka szavaknál egyediségi ponttól függetlenül a legkisebb kapu esetén nem volt helyes válasz – így itt nincs RI sem.

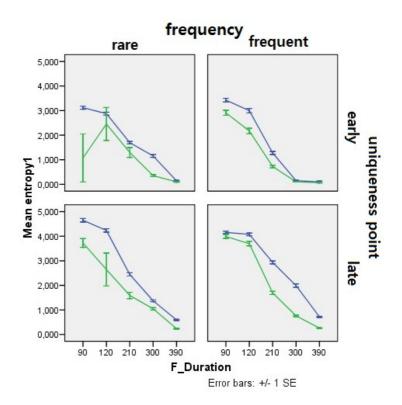
#### Konfidencia



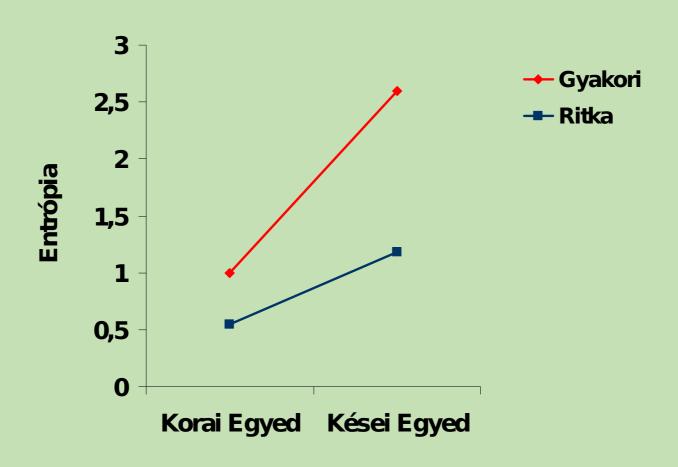
 A megszorítás a gyakorikésői egyediségi pontú szavak esetén a hosszabb kapuktól (210+) kezdve csökkenti a biztossági ítéletet

#### Entrópia és egyediség i pont

Entrópia akkor is szignifikáns, ha az egyediségi pont és a gyakoriság ellenőrzött



### Entrópia magasabb a gyakori szavaknál Egyediségi pont: csökkent entrópia



### Gating

 Az entrópia jó közelítője a szófelismerés pontosságának

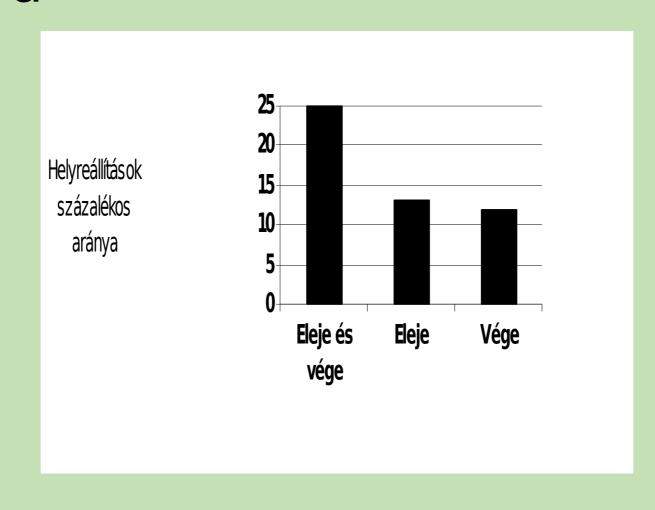
 A top-down megszorítás növeli a pontosságot, de lassítja a válaszadást

 Reakcióidők összevetése az entrópiamutatókkal

#### A szavak eleje számít Fazekas szövegjavítási feladat

Eleje -	vége jó	Eleje jó	Vége jó
Ha mbe szny Pge akái geth Ami	egy pinaglló engbereti a ráát nbiken, az tdoánrot is neszejrt kerában.	A nő nyumlogaar vákgyi. A házsagaás elrtotmol, a láany kamkdioasz- ő	A ágmany acsk sesűrkeéget üszl és aszőrekot. Max enm thite nolva, ohgy a
mde mni öfüs mer csek abá álto a jve	nnedel szegg, nidn ketüedlenk pjalan vtja ztatha meg öőt. Még peklni is	eregy kevbéés tajallá a hetlyé, és úgy ézir, rdviöidőre mujszá tálvo keneirlü a hétkölótpaijzan . Eztré fodjaag el egy bajatrá megtáváhí,	ajsát őrbén Ikel taszegpamtaln ia zet. Jó arzsu olvt, kai glodoban él a leséefge és álksinya lelmett. A

#### A szavak rekonstrukciója sikeresebb, ha mind a szó eleje mind a vége helyesen van leírva

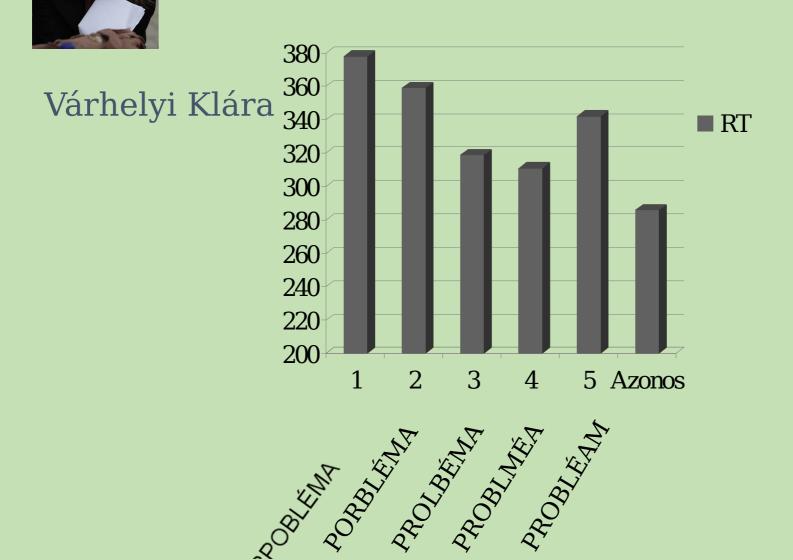


### Az előfeszítési helyzet

RPOBLÉMA

PROBLÉM A

Előfeszítési hatás a kezdetnél: A rontott szó lelassít az elején és a végén



### Összefoglalva

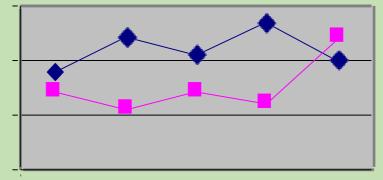
- A szókezdet kiemelkedő jelentősége a hozzáférésben a magyarban is nyilvánvaló
- A szófelismerés érzékenyebb az entrópia értékekre és az alaktani szerkezetre mint magára a gyakoriságra
- Az entrópia változás fontos a szomszédsági hatások értelmezésében

#### Az alaktan

- Szegmentálást segíti: kérdései hangsúly elől, szóalak korlátok
- A töveket és a ragot dolgozzuk fel elsődlegesen (Juhász és Pléh), lassabban, mint az angol vagy olasz
- A végződés feldolgozás már menet közben, hallgatáskor végbemegy (Gerg
   Elemz

defau

Egészlege s Gyakori Egyedi: házasság Irreleváns kattanások felismerése mondat hallgatása közben



csók-ja-id-tól Levedula

#### Döntések hosszú sok morfémás szavaknál: Pléh és Juhász 1995



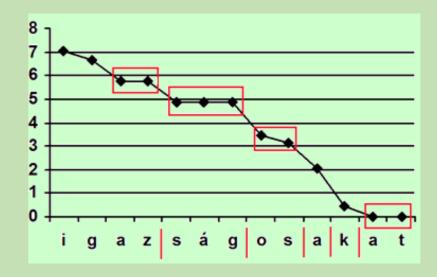


bathtub effect Aithchison

#### Korai felvetések az információs alapú morfológiáról

STUDIUM

• Antal László (1964) a • igaz-ság-os-ak-at szó testében az általános tendencia az entrópia fokozatos csökkenése. Morfémahatáron megszakad ez a csökkenés



#### Szisztematikusa bban Hasonló szavak, mint a gatingnél

- Böll**á**r Tő
- Böllér-**a**k böllér**u**k Jel
- Böllér-nak böllérnuk Rag
- Böllér-ak-nek bölléruk-nek Jel belül



### A vizsgálati anyag alapja

- 60 kétszótagú főnév, Németh Kornél gating vizsgálata alapján
- Forrás: MOKK korpusz (www.szoszablya.hu
   )
- 4 csoport egyediségi pont és gyakoriság alapján

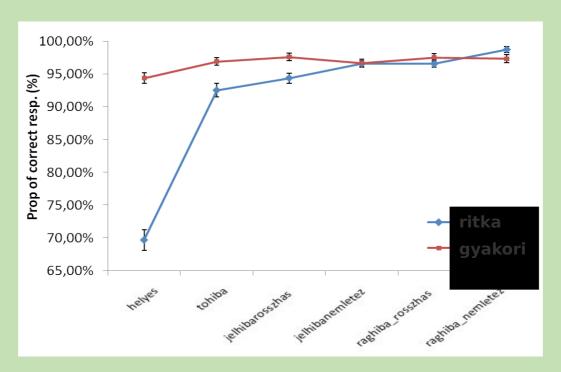
	Gyakor i	Ritka
Korai	kenyér, műsor	böllér , gyűszű
Késő i	város , csapat	pincsi , krokett

### A ragozott szavak

- Előfordulások: csak tő, jel, rag vagy jel és rag
- Rontás a tőben (kunyérem) a jelben (kenyérid) vagy a ragban (kenyeredbun)
- Létező, de rosszul illesztett (kenyérim) vagy nem létező toldalékok (kenyérum)

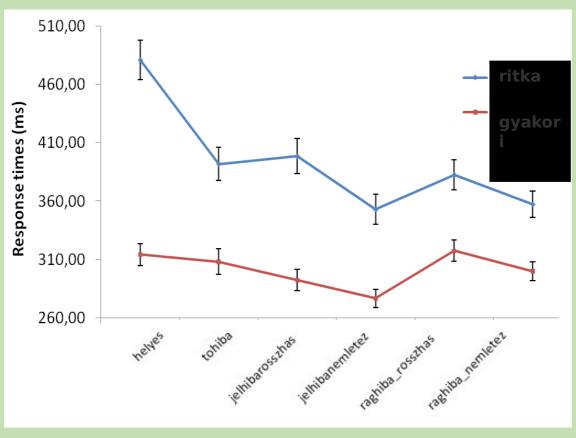
kenyérnek		kenyérben		kenyérr e	
kenyerek	kenyerak/ kenyerik	kenyerem	kenyeram/ kenyerim	kenyer ed	kenyerad/ kenyerid
kenyerekn ek	kenyerakne k/ kenyerikne k	kenyerekb en	kenyerakb en/ kenyeriken	kenyer ekre	kenyerakr a/ kenyerikra
kenyeremn ek	kenyeramn ek/ kenyerimne k	kenyeremb en	kenyeramb en/ kenyerimb en	kenyer emre	kenyeram ra/ kenyerimr e
	lean variadas		lean raisadh		lan varadr

### Eredmények – helyes válaszok



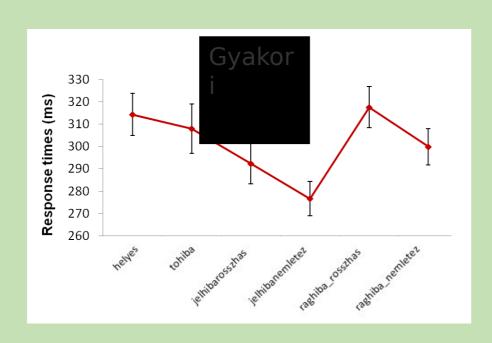
- Mind a gyakoriság mind a hibatípus hatása szignifikáns
- A szó gyakorisága és a hibatípus felismerésének gyakorisága között is szignifikáns korreláció figyelhető meg
- Minél később fordul elő a hiba a szóban, elutasítása annál könnyebb és gyorsabb

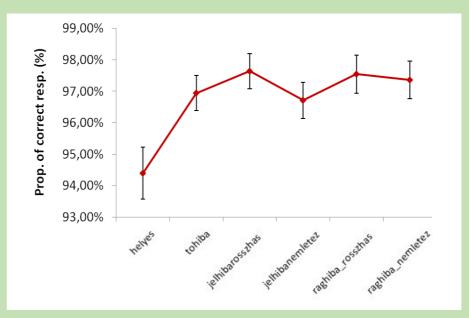
### Eredmények - reakcióidők



- Mind a gyakoriság, mind a hibatípus hatása szignifikáns
- A létező szavak elfogadása lassabb, mint a nem létezők elutasítása
- A nem létező tövek elutasítása lassabb, mint a nem létező toldalékoké
- Nincs egyértelmű fürdőkád hatás
- A két magánhangzó harmóniát sértő hibatípus közt nincs különbég, viszont ezekhez képest a nem létező toldalékok

# Szóközepén előforduló rontások gyakori szavaknál





Reakcióidő

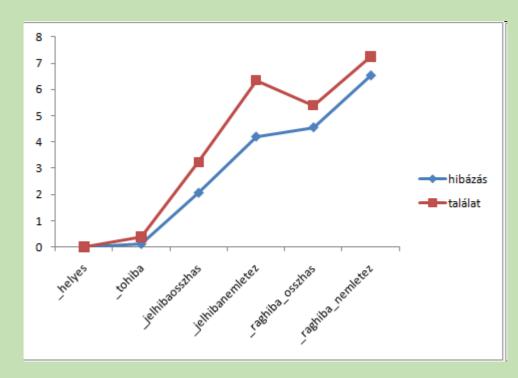
Helyes válaszok

- Gyorsabb reakcióidő, de gyakoribb hibázások
- Lehet egy optimalizálási mechanizmus eredménye

#### A rontás alattomoss ága

- A rontás előtt lévő 4 karakter előfordulási gyakorisága a MOKK korpuszban, pl.: <u>bölléred - böllérud</u> léru-782 előfordulás lére-75283 előfordulás
- A két szám hányadosának logaritmusa (ngram-faktor) határozza meg a rontás alattomosságának a mértékét

#### Eredmények – a rontás alattomossága



A rontás alattomossága minden hibatípus esetében segít a rontások felismerésének bejósolásában

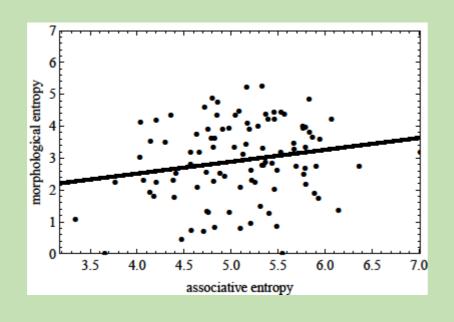
- Az ngram-faktor fordítottan korrelál az alattomossággal
- Minél ritkábban fordul elő a rontás előtti betűnégyes az eredeti betűnégyeshez képest, annál kevésbé alattomos a rontás
- Minél kevésbé alattomos a rontás annál nagyobb eséllyel veszik észre
- A kategoriánként elvégzett repeated measures Anova formálisan is alátámasztja a hipotézist

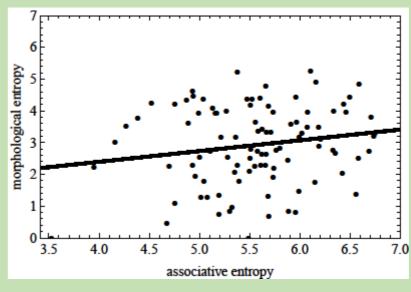
## Alaktani és lexikai entrópia

- Kabát –
- ok
- -ot
- -jaimat

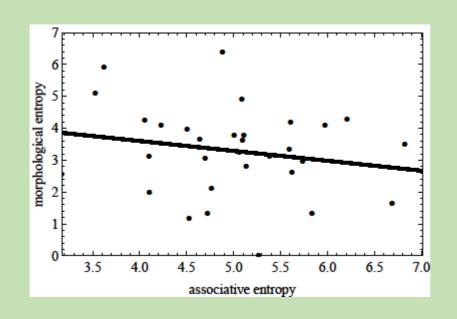
- Kabát kalap
- fogas
- szék

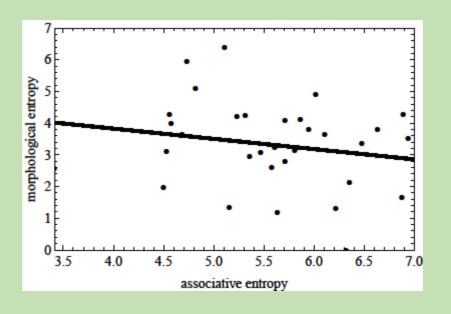
#### Gyenge pozitív korreláció főneveknél 10-14 20-24 A kettő viszonya Czégel, Lengyel és Pléh





## Gyenge negatív korreláció igéknél 10-14 18-24





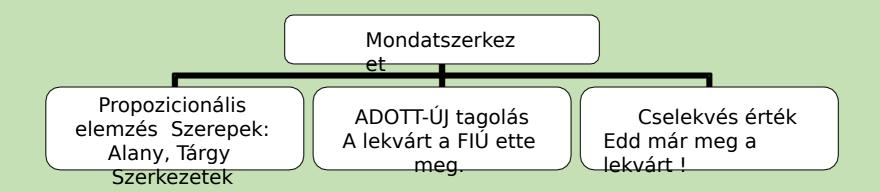
	10-14	18-24
Nouns	0.20	0.18
Verbs	-0.19	-0.19



# Összefoglalás

- A gyakoriság és a hibatípus hatása és ezek kapcsolata mind a helyes válaszok, mind a reakcióidők tekintetében szignifikáns
- Minél később fordul elő a hiba a szóban, elutasítása annál könnyebb és gyorsabb
- A nem létező toldalékok elutasítása lassabb
- Minél alattomosabb egy hiba, annál kisebb eséllyel kerül elutasításra

## A mondat megértés kérdései



# Egy mondat RSVPvel

A magas királyn ő kizsákmányol ta a vacogó rendőrök et a kertben.

## Ellenőrzé s

Királynő

• ker

#### A propozicionális elemzés kérdései • Mondatbeli szerep eldöntése:

- Möndatbeli szerep eldöntése: mit használunk? Szórend, rag, élőség
- Szabályok és Statisztika viszonya
- Tévedések a gyors elemzésben
- Nyelvek eltérései
- A mondatszerkezet felállításának elvei

Nyelvek eltérései a tényezőkben Bates és MacWhinney, 1998

#### Egyszerű mondat értelmezés

### The Competition Model (Bates and MacWhinney, 1982)

Language	Child	Adult	
English	Order > Anim > Agr	Order > Anim > Agr	
French	Order > Anim	Agr > Anim > Order	
Dutch	Order > Case > Anim	Caser > Order > Anim	
Croatian	Anim > Case > Order	Case > Agr > Anim	
Turkish	Case	Case > Anim > Order	
Hungarian	Anim > Case > Order	Case > Order > Agr	
Walpiri	Anim > Case > Order	Case > Anim > Order	

# A különböző tényezők magyarázó értéke

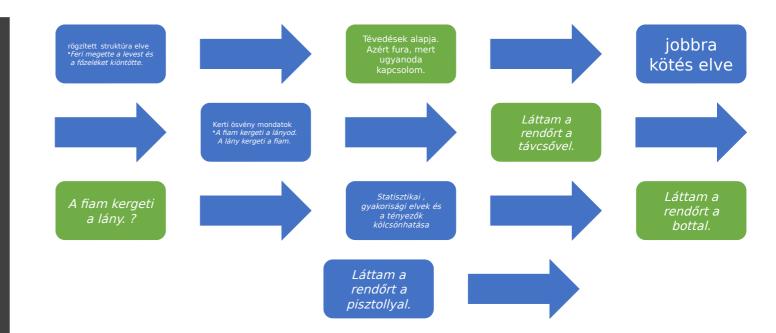
Megnagyári gyermekeknél Macientza kergeti a gyermekeknél

lovat ceruza 0 6 Rag 0 Élőség 5 Szórend 0 Nyom 4 0 aték 0 4 év 3 év 6 év Felnőtt

0

#### A propozicionális

e I e m z é s



# Elvárási hatás és entrópia a mondatmegértés ben

Számos adat az ige és vonzat közti elvárásról

Lehetséges feltételes entrópia hatások

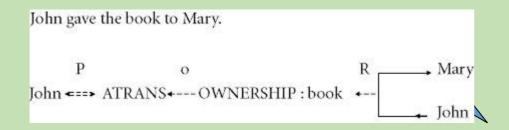
Játszadozás a társakKAL

Magyar ESZKÖZ hatások

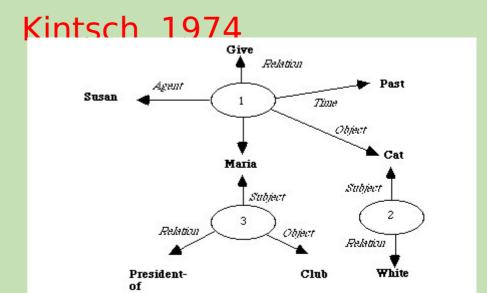
Az ESZKÖZÖk entrópia függő értelmezése

#### Az vonzatelvárás feldolgozási hatásainak szakaszai

- Korai séma elméletek
- Kognitív elvárás

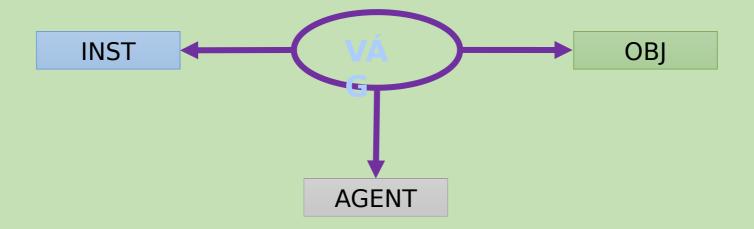


•1972 Schank



A séma alapú feldolgozás alapgondolata

Predikátumok aktiválása az emlékezetből Vonzatok az üres helyekhez rendelése



## Nyelvészeti gondolatmenet

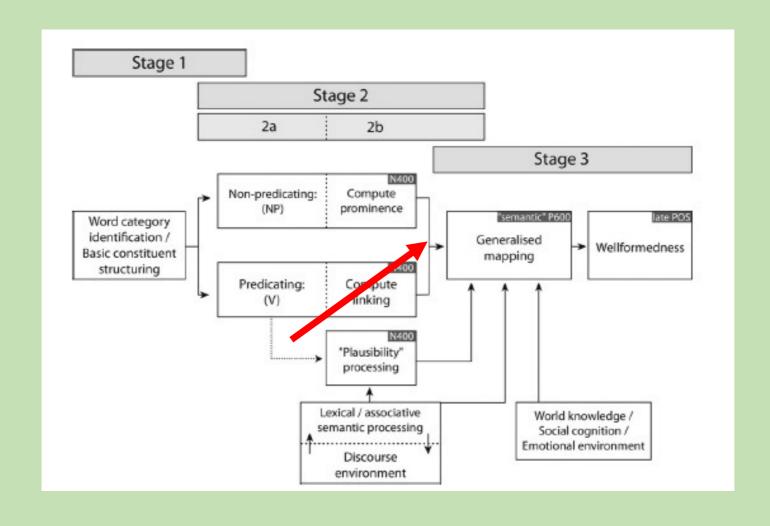
Tematikus szerepek

Kétértelműség a hozzárendelésben

Láttam a rendőrt a távcsővel.

Láttam a rendőrt a pisztollyal.

## Bornkessel and Schmelevsky, 2006



Vonzat viszonyt a rag jelzi

Alternatívák: Gondolkozott a hajón a lányon.

> Többszörö s keretek

Elvont viszonyok helyi ragokkal. *Gondol a lányra* 

Vonzat illetve hely.

*játszik* tárgyatlan, tárgyas, eszköz, társ

# Magyar érdekességek

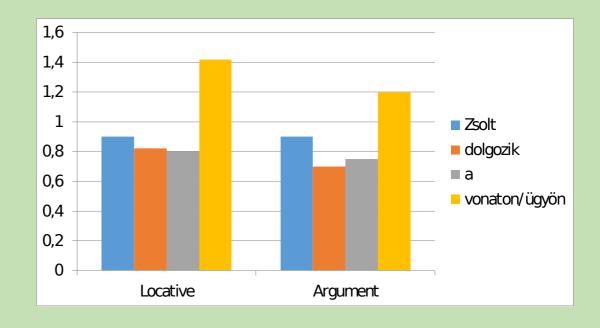
Típus	Példa	
Egyértelmű	Emlékszik a fiúra.	
	Haragszik a tanítóra.	
	Készül a versenyre.	
	Találkozott a lánnyal.	
	Csókolózott a	
	rendőrrel.	
Kétféle vonzat	Gondol a lányra.	
	Gondol valamit.	
Kétértelmű	Gondolkodik a lányon.	
vonzat/határo	Gondolkodik a hajón.	
zó		

# Változat ok

### Gervain és Pléh (2003) lokatív alteráció

 Főnév után kétértelmű vonzat/vagy hely lassabb olvasás





# Fekete és Pléh 2011

Kétirányú: János csókolódzott Marival.

Egyirányú: János kikezeett Marival.

#### A kísérlet releváns igéi

komitative (kétirányú)

Eszköz (egyirányú)

borozott

találkozott

tegeződött

csókolózott

sétálgatott

bulizott

mulatozott

párbajozott

verekedett

énekelt

csipkelődött

foglalkozott

Incselkedett

gúnyolódott

ordított

szimpatizált

csúfolódott

együttérzett

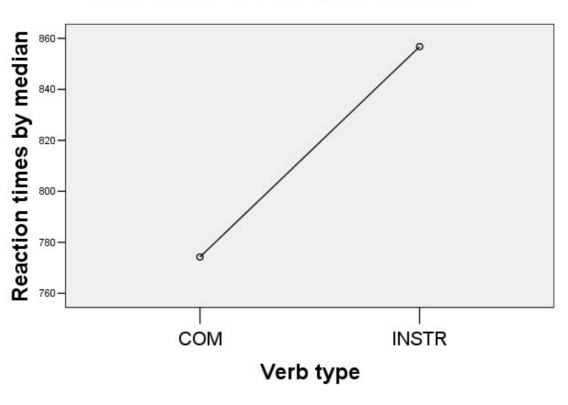
kikezdett

törődött

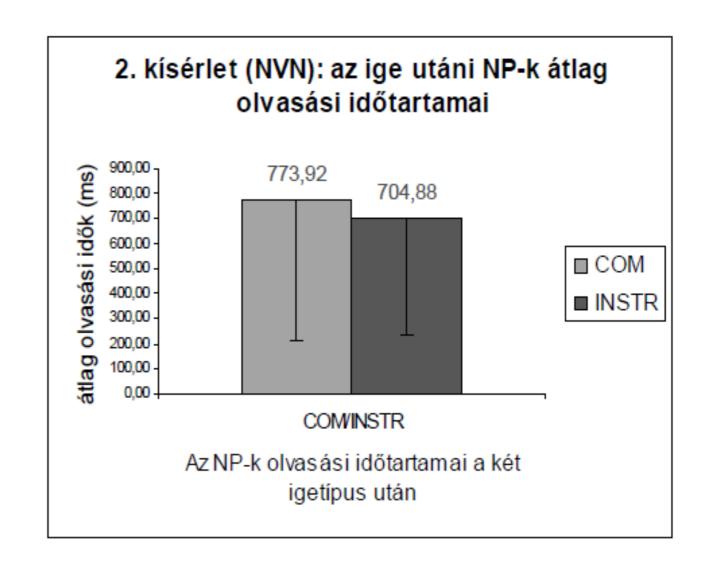
# Teszt mondatok

A lány a fiúval <b>bulizott</b> .	Összejöttek /plul/ másnap.	A lány a fiúval <b>kikezdett</b> .	Összejöttek /plul/ másnap.
	Összejött /sing/ vele.		Összejött /sing/ vele.

#### Main effect of verb type (word 5)



A vonzatot egyirányú ige után gyorsabba n olvassuk

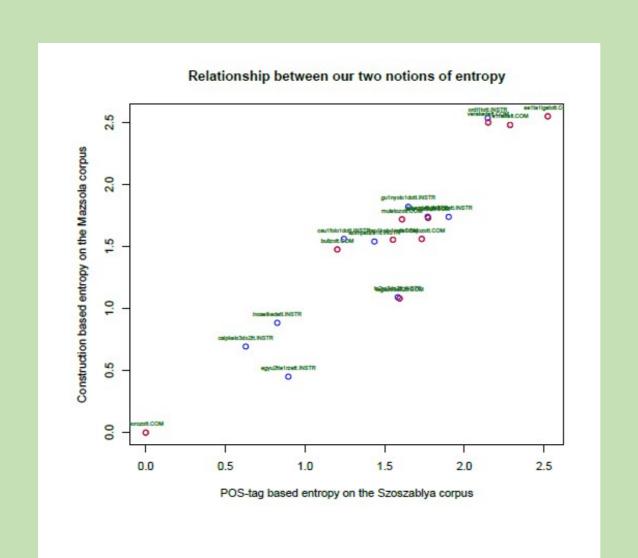


# Újraelemzés az entrópia segítségével

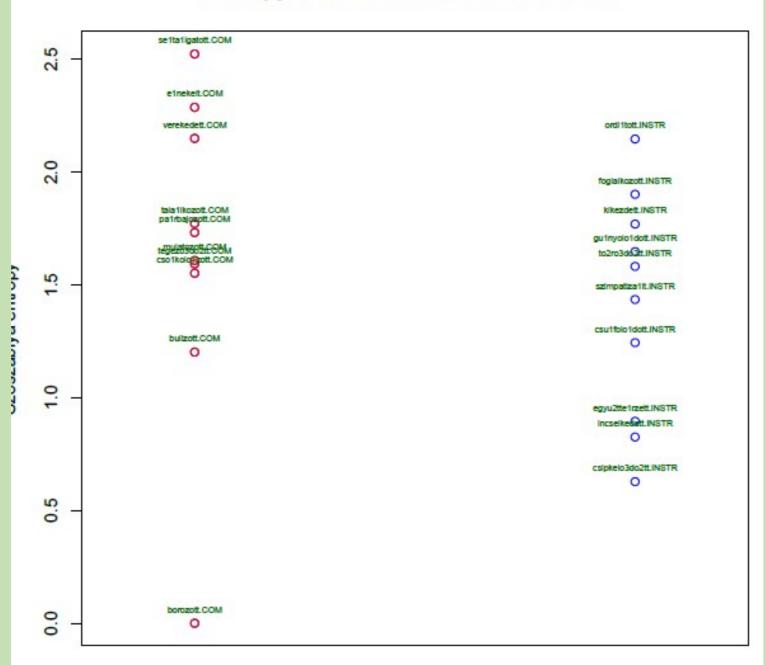
 Az ige entrópiája: mennyire követheti változatos esetkeretű főnév ?

$$H(W) = -\sum_{w \in W} p(w) \log_2 p(w)$$

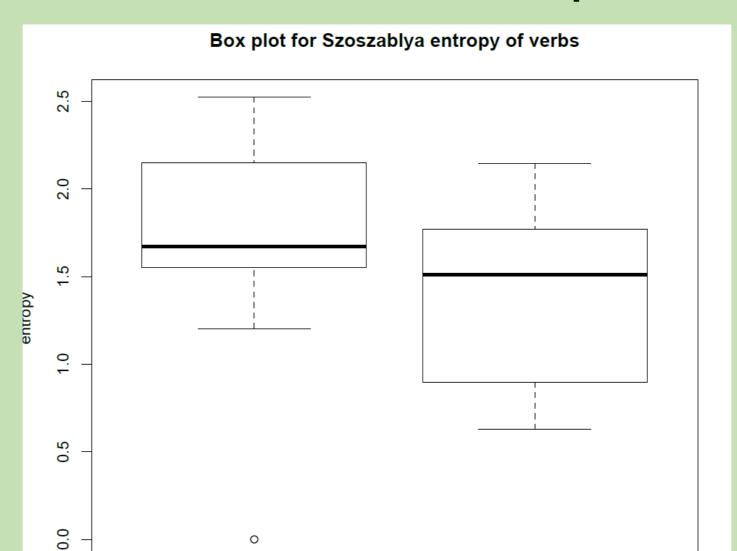
#### Két korpuszból elég közeli entrópia értékek



#### Entropy values for COM and INSTR verbs



# A COMMIT entrópia magasabb sétált szimpatizált



#### Relationship between within verb-pair relative response time and entropy se1ta1lgatott.COM 5. tala1lkozott.COM O csipkelo3do2tt.INSTR entropy difference within pair: COM minus INST 0. O egyu2tte1rzett.INSTR 0.5 e1nekelt.COM O ordi1tott.INSTR tegezo3do2tt.0 0.0 -0.5 bulizott.COM O kikezdett.INSTR -1.0 -1.5 borozott.COM O to2ro3do2tt.INSTR 50 100 150 w5 response time difference within pair: COM minus INST

# Predikciós összefoglal ás

## Értelmezés

Az entrópia fontos mozzanat a nyelvi folyamatoknak.

**Tanulási szempontból** a szótári entrópia hatások azt sugallják, hogy mintavételes statisztikai eljárásokkal a környezeti szókincs leképeződik az egyéni mentális szótárban.

**Feldolgozási tekintetben** a "megértés" egyik mozzanat az a pont, amikor lecsökken a bizonytalanság. Ez igaz szavak, szóalakok és mondatok viszonyában is.

# Akkor a megértés út az unalomhoz?

A bizonytalanság redukcióval párhuzamosan a referenciák és tényállások strukturális alapú feldolgozása a való világ bizonytalanságainak felel meg. A feldolgozás 'belső' oldala a bizonytalanság csökkentését keresi, míg a "külső oldala" az újdonsággal telei világra nyitott.

# Remélem ez csökkentett bizonyos entrópiát

De új bizonytqlanságokat hozott létre